

# Diagnóstico automático de fallas en rodamientos de máquinas rotativas a partir del análisis de señales de vibración empleando modelos ocultos de Markov por capas.

**Jorge Luis Fernández Ramírez**

Trabajo de grado presentado como requisito parcial  
para optar al título de  
Ingeniero Electricista



Facultad de Ingenierías  
Universidad Tecnológica de Pereira  
Grupo de investigación en Automática  
Colombia  
2 de julio de 2017

Diagnóstico automático de fallas en rodamientos de máquinas rotativas a partir del análisis de señales de vibración empleando modelos ocultos de Markov por capas.  
©Jorge Luis Fernández Ramírez

Director: PhD. Álvaro Ángel Orozco Gutiérrez

Pereira, 2 de julio de 2017  
Programa de ingeniería eléctrica.  
Universidad tecnológica de Pereira.  
La Julita. Pereira, Colombia.  
TEL: (+57)(6) 3137122  
*www.utp.edu.co*

# Dedicatoria

# Agradecimientos

Quiero agradecer al grupo de investigación en automática por el acompañamiento y la orientación brindada durante el desarrollo de este trabajo, en especial a todas aquellas personas que de una u otra forma aportaron para que este trabajo se realizara lo mejor posible.

# Diagnóstico automático de fallas en rodamientos de máquinas rotativas a partir del análisis de señales de vibración empleando modelos ocultos de Markov por capas.

Jorge Luis Fernández Ramírez

## Resumen

Entre los métodos para la detección y diagnóstico de fallas en rodamientos se encuentran las técnicas basadas en el análisis de: vibración, temperatura, corriente, sonido, etc. Siendo aquellos basados en el análisis de señales de vibración los más comunes y que mejor resultado presentan [2]. En la operación de los rodamientos cuando los elementos rodantes pasan por encima de un defecto se produce una amplia banda de impulsos a una frecuencia determinada por: la rotación del eje, la geometría de los rodamientos y la localización del defecto (anillo externo, anillo interno o en bola) [16]. El principal interés en este análisis es programar la reparación de la máquina en una etapa temprana del fallo y en un lapso en el que la máquina no tenga que detener su producción súbitamente. Por lo tanto, es una optimización de un proceso en el área del mantenimiento preventivo, con un seguimiento de los síntomas de falla a partir de las señales de vibración obtenidas de un transductor, en este caso un acelerómetro, que corresponde a una metodología de carácter no invasivo y no destructivo [15].

Este trabajo presenta una metodología para el diagnóstico de fallas en rodamientos, e identificación de condiciones operacionales de máquinas eléctricas rotativas, basado en el análisis de señales de vibraciones mecánicas. El método desarrollado consta de cuatro fases, en la primera se realiza una extracción de características a partir de intervalos de cuasi-estacionariedad, cuyo fin es disminuir la dimensionalidad y posibilitar el moldeamiento probabilístico de las señales [25].

En la segunda fase se busca implementar una metodología para realizar la clasificación de señales de acuerdo a su dinámica, tal que, cuando ingrese una nueva señal al sistema, este se encuentre en capacidad de asociarla a una dinámica conocida. Para esto se utiliza una herramienta de modelado probabilístico robusta, llamada Modelos ocultos de Markov, la cual es utilizada en gran medida en campos de reconocimiento de voz, generación automática de escritos y de clasificación en general [22]. Esta herramienta busca modelar la fuente que generó a las observaciones, haciendo posible un reconocimiento de patrones detallado y preciso. Dentro de esta fase se encuentra la implementación de la estrategia de poda de estados y de varios criterios para la selección del modelo, para obtener automáticamente el número de estados para los modelos.

En la tercera fase, se propone realizar la clasificación de señales de vibración por capas, con esta metodología se disminuye la cantidad de modelos que se deben entrenar y por lo tanto, durante la validación se debe comprobar la pertenencia de

una nueva señal, con una menor cantidad de clases. Representando una disminución significativa del tiempo de computo, manteniendo un porcentaje de precisión alto.

Finalmente, en la cuarta fase, se realizó la validación estadística de los modelos obtenidos en el entrenamiento, donde se obtuvo el espacio de representación adecuado para resaltar las dinámicas intrínsecas de las señales, se comprobó la veracidad del algoritmo para obtener el número de estados óptimo y se realizó la comparación entre la forma convencional de realizar la clasificación y la propuesta en este trabajo.

# Índice general

<b>1. Introducción</b>	<b>1</b>
1.1. Planteamiento del problema . . . . .	1
1.2. Justificación . . . . .	2
1.3. Objetivos . . . . .	3
1.3.1. Objetivo general . . . . .	3
1.3.2. Objetivos específicos . . . . .	3
1.4. Estado del arte . . . . .	3
1.5. Alcance . . . . .	4
1.6. Estructura del trabajo de grado . . . . .	5
<b>2. Marco Conceptual</b>	<b>6</b>
2.1. Notación básica . . . . .	6
2.2. Transformada wavelet . . . . .	6
2.3. Conjunto de descriptores estadísticos . . . . .	7
2.4. Clasificador de vecinos más cercanos (KNN) . . . . .	7
2.5. T-test . . . . .	8
2.6. F test . . . . .	8
2.7. Estacionariedad . . . . .	9
2.8. Transformada Fourier en tiempo discreto . . . . .	10
2.9. Transformada rápida de Fourier . . . . .	10
2.10. Coeficientes cepstrales en la frecuencia Mel (MFCC) . . . . .	11
2.11. Modelos Ocultos de Markov . . . . .	11
2.11.1. Notación básica Modelos Ocultos de Markov . . . . .	12
2.11.2. Notación para modelos de densidad continua . . . . .	13
2.11.3. Problemas asociados a los modelos ocultos de Markov . . . . .	13
2.11.4. Criterio de información de Akaike . . . . .	14
2.11.5. Criterio de información Bayesiana . . . . .	15
2.11.6. Criterio de longitud mínima de descripción de mezcla . . . . .	15
<b>3. Materiales y métodos</b>	<b>16</b>
3.1. Base de datos de señales de vibraciones . . . . .	16
3.1.1. Base de datos de la Universidad Salesiana de Cuenca . . . . .	16
3.1.2. Base de datos de la universidad Western Reserve . . . . .	18
3.1.3. Método para realizar el pre-procesamiento . . . . .	19
3.2. Método para realizar el Test de estacionariedad . . . . .	20

---

3.3. Método de extracción de características de ventaneo en frecuencia . .	20
3.4. Método para la extracción de los coeficientes MFCC . . . . .	21
3.5. Método secuencial de poda de estados . . . . .	21
3.6. Método de clasificación por capas . . . . .	22
<b>4. Implementación y validación de resultados</b>	<b>23</b>
4.1. Pre-procesamiento . . . . .	23
4.2. Resultado de evaluar la cuasi-estacionariedad de señales de vibración	24
4.3. Estrategia de la poda de estados . . . . .	27
4.4. Validación de resultados . . . . .	30
4.4.1. Validación cruzada . . . . .	30
4.4.2. Matriz de confusión . . . . .	32
4.4.3. Validación cruzada anidada . . . . .	34
4.5. Modelos Ocultos de Markov por capas . . . . .	36
4.6. Resultados obtenidos al emplear la base de datos de la universidad	
Western Reserve . . . . .	37
<b>5. Conclusiones</b>	<b>40</b>



# Capítulo 1

## Introducción

### 1.1. Planteamiento del problema

Los rodamientos son un componente mecánico de las máquinas rotativas que se encargan de acoplar elementos y reducir la fricción. Debido al movimiento relativo entre las superficies de contacto, dichos rodamientos son propensos a sufrir fallas. Hwang en [13] ha identificado que la principal causa de fallo en las máquinas está relacionada al estado de los rodamientos, se menciona que cerca del 40 % de las fallas en los motores son debidas a estos. Por lo tanto, la identificación de fallas en rodamientos utilizando técnicas de monitoreo ha sido sujeto de investigación en las pasadas décadas. Se ha determinado que las causas más comunes para el fallo de los rodamientos son: el desembalaje, la desalineación, la lubricación insuficiente, la sobre carga, la corrosión y los errores de manufactura [21].

La dificultad en la detección de defectos en rodamientos radica en que las características del fallo se encuentran esparcidas en una amplia banda de frecuencias y pueden ser fácilmente enmascaradas por ruido o efectos de baja frecuencia [21]. Por lo tanto, es necesario emplear transformaciones de las señales de vibración, para que las dinámicas presentes en ellas puedan ser discriminadas más fácilmente.

Actualmente la detección automática de fallas se ha abordado a partir de dos enfoques diferentes: El primero, es un enfoque basado en aprendizaje con el surgimiento de la inteligencia artificial, técnicas como redes neuronales, lógica difusa y sistemas expertos, pueden abordar el problema de forma más efectiva. Las redes neuronales artificiales (ANN) tienen habilidades como aprendizaje superior, eliminación del ruido y son computacionalmente eficientes, sin embargo, una implementación adecuada depende de una elección apropiada del tipo red y de un set de información amplio para el entrenamiento, que no está siempre disponible [21]. La lógica difusa puede ser desacertada en aplicaciones complejas [14]. Los sistemas expertos han sido utilizados en problemas complejos, sin embargo, los algoritmos son difíciles de actualizar para cada sistema objetivo, en [6] se sugiere que esta técnica no podría ser aplicada de forma genérica debido a falta de conocimiento.

El segundo enfoque está basado en datos estadísticos y surge debido a las limitaciones presentadas por las técnicas basadas en aprendizaje. Es un método alternativo encontrado por los investigadores para mejorar el monitoreo del estado de la maqui-

naria.

Al utilizar modelos ocultos de Markov para modelar dinámicas, se presenta el problema de inferir los parámetros libres de forma eficiente, en este caso el número de estados de la cadena de Markov. Es sabido que esta herramienta tarda mucho tiempo para ser entrenada y fácilmente, puede sobre dimensionar el modelado del fenómeno, al elegir muchos estados, repercutiendo en el incremento del tiempo de cómputo y requerimientos de memoria, sin obtener una mejora notable en la precisión del clasificador. Por lo tanto, determinar el número de estados de forma automática juega un papel fundamental al realizar el moldeamiento probabilístico de las dinámicas intrínsecas de las señales de vibración [3].

La forma convencional de abordar la clasificación al emplear modelos ocultos de Markov, es generar un HMM por cada una de las dinámicas o clases presentes en la base de datos, y aplicar la regla de decisión de Bayes para definir la pertenencia de las señales de validación en los diferentes modelos entrenados [3, 15, 6]. El problema con esta metodología consiste en que cuando se aumenta el número de modelos, el tiempo que tarda entrenar el sistema de clasificación y posteriormente validarlo, aumenta sustancialmente, requiriéndose de mayor capacidad de procesamiento para revertir este efecto, lo cual no siempre es posible. Dado lo anterior surge la pregunta ¿es posible desarrollar una metodología para realizar la clasificación de señales de vibración disminuyendo el tiempo de computo y manteniendo un porcentaje de precisión alto?

## 1.2. Justificación

Las máquinas eléctricas rotativas son una pieza esencial en el sector industrial, debido a que tienen características muy deseables: evitan la acumulación de residuos contaminantes producidos por combustibles y no necesitan ventilación, entre otros. En este sector es importante que los procesos sean cada vez más confiables y que las máquinas estén siempre disponibles, por lo tanto, se debe implementar un adecuado esquema de monitoreo de la maquinaria para que se aumente la productividad, la confiabilidad y se reduzcan los costos de mantenimiento. Un adecuado esquema de monitoreo es aquel que está en capacidad de detectar el estado de la máquina (normal o en falla), identificar la severidad del fallo y hacer recomendaciones de mantenimiento [6]. Con procesos y maquinaria más complejos, la necesidad de un sistema de diagnóstico de fallas automático se hace aún más necesario, debido a que las acciones de mantenimiento deben hacerse de forma inmediata.

En reconocimiento de patrones se presentan problemas como incertidumbre, aleatoriedad y vacíos, que son originados por fuentes externas. Es sabido que los modelos estocásticos lidian con estos problemas de forma eficiente y han demostrado no tener las limitaciones presentadas por las técnicas basadas en aprendizaje [6, 21, 14]. Por esto se implementa en este trabajo modelos ocultos de Markov, que son modelos estocásticos con una estructura matemática robusta, que se han implementado exitosamente para modelar señales estacionarias y no estacionarias [16]. Sin embargo, se desataca la necesidad de implementar una estrategia para realizar la clasificación,

que sea eficiente computacionalmente, debido a que entrenar los modelos y validar el sistema de clasificación, requiere de mucho tiempo.

En el campo del monitoreo de la máquina, se busca una evolución constante de las metodologías y técnicas, debido a que las exigencias que se presentan en la industria son cada vez mayores, y se requiere hacer más preciso el monitoreo de la máquina y más acertado el diagnóstico de fallas en etapas tempranas. Por lo tanto, los investigadores han ahondado en el tema, pues representa un reto técnicamente y es muy rentable el desarrollo de nuevas metodologías y técnicas [6]. Una de las tendencias que se ha presentado en el estado del arte es la búsqueda de eficiencia computacional, entendiéndose como minimizar el tiempo de cómputo y los requerimientos de memoria para las aplicaciones, manteniendo o mejorando la precisión al detectar y clasificación de fallas, por esto, se pretende determinar en este trabajo qué espacio de representación discrimina mejor entre las dinámicas presentes en las señales, tal que se genere mayor precisión al realizar la clasificación. Finalmente, se quiere comprobar, si la estrategia propuesta para realizar la clasificación efectivamente disminuye el tiempo de computo manteniendo un porcentaje de acierto alto.

## 1.3. Objetivos

### 1.3.1. Objetivo general

Desarrollar una metodología para el diagnóstico automático de fallas en rodamientos de máquinas rotativas utilizando modelos estocásticos.

### 1.3.2. Objetivos específicos

- Desarrollar una metodología para estimar los parámetros de un modelo oculto de Markov, que incorpore la selección automática del número de estados.
- Desarrollar un sistema de clasificación de señales de vibraciones mecánicas, basado en un análisis por capas.
- Validar estadísticamente el desempeño de la metodología desarrollada, en cuanto a la precisión del sistema de clasificación basado en modelos ocultos de Markov.

## 1.4. Estado del arte

La detección de fallas en rodamientos de máquinas rotativas a partir de técnicas de monitoreo ha sido sujeto de estudio en múltiples investigaciones, debido a que un problema de este tipo puede ocasionar una parada súbita en la producción de la máquina [16]. En muchas investigaciones se ha demostrado la importancia de segmentar la señal de vibración, sea por medio algoritmos recomendados por Ingenieros expertos en vibraciones [13] o por prácticas operativas que han probado ser

adecuadas para otros investigadores [15]. Debido a que: 1) Señales más cortas tienen menores tiempo de cómputo y menores requerimientos de memoria. 2) Se mejora la localización de fallas, debido a la utilización de mejor resolución en la frecuencia mediante la caracterización con diferentes representaciones [2].

Para superar la dificultad en la caracterización de señales, se han propuesto las representaciones en tiempo, frecuencia y tiempo-frecuencia. Siendo estas últimas las más utilizadas porque además de emplear características frecuenciales, se tiene en consideración su ocurrencia temporal, sin embargo, cuando se tiene en cuenta muchos instantes temporales al realizar la clasificación, se satura la memoria del computador, haciendo que este procese la información muy lentamente. Por lo tanto, se propone seguir la metodología planteada en [21, 15], donde se representan un análisis por ventanas de tiempo, en las cuales se realiza la extracción de un set de características estadísticas del espectro de las señales, este se compone de descriptores estadísticos que son sensibles a las oscilaciones impulsivas comunes en las señales de vibración de rodamientos con falla.

Por otro lado, Los coeficientes cepstrales en la frecuencia Mel, están basados en una representación no lineal del sonido y han sido utilizados exitosamente en aplicaciones de reconocimiento de voz [19], debido a que realizan una aproximación muy acertada de la respuesta del sistema auditivo humanos. Se propone en [25] que esta metodología puede ser aplicada para realizar una mejor representación de las dinámicas de las señales, siendo adecuado para utilizar en conjunto con los modelos ocultos de Markov, debido a que son coeficientes presentes en ventanas secuenciales definidas por filtros pasa bandas.

En diferentes estudios [12, 5, 6, 21], se presentan sistemas de clasificación basados en el entrenamiento de modelos ocultos de Markov, utilizando características obtenidas en espacios de representación temporales y frecuenciales, sin embargo, no se presenta un análisis comparativo entre las metodologías que mejor resultado han presentado. Por el contrario, se ha optado por demostrar el poder de extraer dichas características ante diferentes situaciones, por ejemplo, con adición de ruido Gaussiano. Es por lo tanto oportuno realizar un análisis comparativo entre las metodologías que han demostrado ser más efectivas y poner a prueba el sistema de clasificación con un problema de mayor complejidad.

Para el entrenamiento de los modelos se tendrá en cuenta los esquemas planteados en [21, 6, 16, 3], en donde se implementan modelos similares y además se desglosan conceptos básicos para su correcta aplicación. Se tiene en cuenta, que los resultados presentados por los correspondientes autores son satisfactorios, lo que supone que el desarrollo de la aplicación de interés este bien encaminada.

## 1.5. Alcance

Este trabajo busca realizar un análisis comparativo entre dos de las metodologías de extracción de características que mejor resultado han presentado en el estado del arte y, además, comprobar la veracidad, mediante validación cruzada anidada, de la metodología para determinar automáticamente el número de estados optimo,

utilizando criterios de teoría de la información, para modelos ocultos de Markov utilizados para modelar las señales de vibración. La base de datos con la que se trabajara fue fabricada en el laboratorio de la Universidad Politécnica Salesiana de Ecuador y fue suministrada por el grupo de investigación en automática de la Universidad Tecnológica de Pereira.

Se probará el sistema de clasificación realizando un diagnostico automático de fallas en rodamientos, y de igual forma, identificando la condición operacional correspondiente, con lo que se corroboraría la robustez de los modelos ocultos de Markov para el reconocimiento de patrones.

## 1.6. Estructura del trabajo de grado

Este trabajo de grado está organizado de la siguiente forma: En el capítulo 2 se presentan el enfoque teórico utilizado para realizar la extracción de características y obtener los parámetros de los Modelos ocultos de Markov, además de sus problemas asociados. En el capítulo 3, se presentan la implementación de los algoritmos y la validación estadística de sus resultados. Finalmente, en el capítulo 4 se presentan las conclusiones y aportes más significativos del trabajo de grado.

Figura 1.1: Diagrama de flujo del sistema de clasificación implementado.

# Capítulo 2

## Marco Conceptual

### 2.1. Notación básica

- $x(n)$ . Señal de vibración en tiempo discreto.
- $W_\phi(j_0, k)$ . Es el coeficiente de aproximación de la expansión wavelet.
- $\phi_{j_0, k}(n)$ . Se conoce como función de escala en la expansión wavelet.
- $W_\psi(j, k)$ . Es el coeficiente de detalle de la expansión wavelet.
- $\psi_{j, k}(n)$ . Se conoce como wavelet madre en la expansión wavelet.
- $\bar{X}$ . Media muestral.
- $\bar{S}$ . Desviación estándar muestral.
- $x(\omega_k)$ . Espectro de Fourier discretizado.
- $S(i)$ . Es el logaritmo a la salida del banco de filtros al calcular coeficientes MFCC.
- $c(n)$ . Coeficientes MFCC.

### 2.2. Transformada wavelet

La transformada wavelet (WT), es una herramienta utilizada en el análisis de señales, que supera las dificultades enfrentadas por otras técnicas en el procesamiento de señales transitorias, no estacionarias, o cambiantes en el tiempo. La Transformada wavelet permite emplear largos intervalos de tiempo donde se desea obtener la información contenida en baja frecuencia, y a su vez, permite emplear cortos intervalos de tiempo donde se desea resaltar la información contenida en alta frecuencia. La mayor ventaja que se obtiene empleando wavelets es la habilidad de realizar análisis local de una señal, o realizar un acercamiento en cualquier intervalo del tiempo sin perder la información espectral contenida allí. El análisis mediante wavelets es, por lo tanto, capaz de revelar algunos aspectos escondidos de la información en las señales, que otras técnicas de análisis de señales no detectan. esta propiedad es importante en particular para aplicaciones de detección de fallas [7].

Los coeficientes en la siguiente expansión se conocen como la Transformada wavelet discreta (DWT), de la serie  $x(n)$ .

$$x(n) = \frac{1}{\sqrt{M}} \sum_k W_\phi(j_0, k) \phi_{j_0, k}(n) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi(j, k) \psi_{j, k}(n) \quad (2.1)$$

donde  $j$  es el índice de escala,  $k$  es la traslación en el tiempo y  $M$  es la cantidad de puntos de las series.

Si el sistema conformado es ortogonal, estos coeficientes pueden ser calculados mediante productos internos.

*Coeficiente de aproximación:*

$$W_\phi(j_0, k) = \langle x(n), \phi_{j_0, k}(n) \rangle = \frac{1}{\sqrt{M}} \sum_n x(n) \phi_{j_0, k}(n) \quad (2.2)$$

donde  $\phi_{j_0, k}(n)$  se conoce como la función de escala.

*Coeficiente de detalle:*

$$W_\psi(j, k) = \langle x(n), \psi_{j, k}(n) \rangle = \frac{1}{\sqrt{M}} \sum_n x(n) \psi_{j, k}(n), j \geq j_0 \quad (2.3)$$

donde  $\psi_{j, k}(n)$  se conoce como wavelet madre.

## 2.3. Conjunto de descriptores estadísticos

Se conformo este set de descriptores debido a que son sensibles a las oscilaciones impulsivas comunes en las señales de vibración de rodamientos con falla. El set está compuesto por: Valor máximo, Valor mínimo, Media, Media armónica, Rango, Rango Intercuartil, Factor de asimetría, Mediana, Varianza, Kurtosis, Valor RMS, Factor de cresta [21, 11].

## 2.4. Clasificador de vecinos más cercanos (KNN)

Es un algoritmo simple y, por lo tanto, atractivo para realizar pruebas de clasificación de patrones. Su lógica se basa en realizar una estimación de la probabilidad de pertenecer a una clase debido a la cercanía con los vecinos. Para la clasificación de una muestra se toman como referencia los valores de cercanía los  $k$  (número impar para evitar la incertidumbre) vecinos más próximos mediante separación Gaussiana, para la cual se deben normalizar las características de todas las muestras, restando la media y dividiendo por desviación estándar de las muestras elegidas para el entrenamiento, paso seguido se debe medir la distancia euclidiana entre muestras. Se establecen las distancias de menor valor hasta los  $k$  vecinos y finalmente se clasifica la muestra en la clase a la que pertenezca el mayor número de los  $k$  vecinos involucrados [4].

## 2.5. T-test

El test busca poner a prueba la hipótesis de que la media de una serie de datos sea estacionaria, mediante la comparación entre muestras de un parámetro local.

Es, por lo tanto, un test paramétrico que se realiza sobre dos muestras (aleatorias y de distribución normal) independientes y adyacentes, donde se pone a prueba la hipótesis de que estas muestras tengan medias iguales. Por otro lado, las varianzas serán asumidas iguales, aunque estas sean desconocidas [23].

- Calcular la media muestral  $\bar{X}_1$  y la desviación estándar muestral  $S_1$  de un trozo de la señal.
- Calcular la media muestral  $\bar{X}_2$  y la desviación estándar muestral  $S_2$  de un trozo diferente de la señal.

A continuación, se propone la hipótesis que la secuencia es estacionaria en media y se desea aceptar esta hipótesis nula.

$$H_o : \mu_1 - \mu_2 = 0 \quad (2.4)$$

Vs

$$H_1 : \mu_1 - \mu_2 \neq 0 \quad (2.5)$$

Aplicando el siguiente test estadístico:

$$T = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{(S_1)^2}{n} - \frac{(S_2)^2}{m}}} \quad (2.6)$$

Donde  $n$  y  $m$  son los tamaños de las muestras.

Cuando se asume que las muestras son de poblaciones con igual varianza, el test estadístico bajo la hipótesis nula planteada tiene distribución *Student's t* con  $n + m - 2$  grados de libertad.

La ecuación 2.6 es utilizada para probar la hipótesis de que dos medias sean iguales, cuando se evalúa en la región crítica:

$$|T| > t_{n+m-2, \alpha/2} \quad (2.7)$$

Si se cumple la desigualdad, la hipótesis nula es rechazada.

## 2.6. F test

El test busca poner a prueba la hipótesis de que la varianza de una serie de datos sea estacionaria, comparando las varianzas muestrales al obtener su cociente.



Este test se realiza sobre dos muestras (aleatorias y de distribución normal) independientes y adyacentes, si ambas muestras son de la misma distribución, el cociente entre las varianzas muestrales  $S_1^2$  y  $S_2^2$  tiene distribución F, con los grados de libertad del numerador iguales a  $n_1 - 1$  y los grados de libertad del denominador iguales  $n_2 - 1$ , siendo  $n_1$  y  $n_2$  los tamaños de cada muestra [23].

$$F = \frac{S_1^2}{S_2^2} \quad (2.8)$$

A continuación, se propone la hipótesis que la secuencia es estacionaria en varianza y se desea aceptar esta hipótesis nula.

$$H_o : \sigma_1^2 = \sigma_2^2 \quad (2.9)$$

Vs

$$H_1 : \sigma_1^2 > \sigma_2^2 \quad (2.10)$$

La ecuación 2.8 es utilizada para probar la hipótesis de que una secuencia sea estacionaria en varianza, cuando se evalúa en la región crítica:

$$\frac{S_1^2}{S_2^2} > F_{n_1, n_2} \quad (2.11)$$

Si se cumple la desigualdad, la hipótesis nula es rechazada.

## 2.7. Estacionariedad

Un proceso aleatorio es estacionario si la función de distribución de probabilidad obtenida para un conjunto es invariante con respecto al paso del tiempo [23].

Aceptando la hipótesis de que todas las señales de vibración generadas por máquinas rotativas pueden ser clasificadas como procesos gaussianos aleatorios, en donde algunos componentes no varían periódicamente y además son independientes de algunas variables genéricas, la estacionariedad en sentido débil implica estacionariedad en sentido estricto y es por lo tanto, posible evaluar la estacionariedad de una señal si sus momentos estadísticos son invariantes con el paso del tiempo [11, 24].

En forma discreta los momentos se obtienen mediante la siguiente ecuación:

$$M_r = \frac{1}{N} \sum_{k=1}^N (X_k - \bar{X})^r \quad (2.12)$$

Donde  $N$  es el número de muestras y  $r$  el orden del momento.

El primer momento es la media y corresponde a un valor promedio de la variable.

El segundo momento es la varianza y es la desviación de las muestras con respecto a la media.

## 2.8. Transformada Fourier en tiempo discreto

Tradicionalmente el análisis de señales de vibración se ha basado en el análisis espectral, a partir de La Transformada de Fourier en Tiempo Discreto (DTFT), esta técnica transforma una señal  $x(n)$  en tiempo discreto a una señal en el dominio de la frecuencia conocida como espectro de Fourier 2.13. Se denota  $x(\omega_k)$  el espectro de Fourier que considera un conjunto discreto de frecuencias [20].

$$x(\omega_k) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega_k n}. \quad (2.13)$$

donde:

- $\omega_k = 2\pi k/N$ .
- $k = 0, 1, \dots, N - 1$ .
- $N$ , es el número finito de puntos en los que se evalúa  $x(\omega)$  en el intervalo  $[-\pi, \pi]$ .

$x(n)$  es una señal de vibración en tiempo discreto y  $x(\omega_k)$  es la transformada de Fourier de una señal en tiempo discreto y puede tomar valores complejos.

La DTFT está limitada a que, una vez realizada la transformación del dominio temporal al dominio de la frecuencia, no es posible identificar los instantes de tiempo en los que ocurren los cambios en la dinámica de la señal. Por lo tanto, esta técnica no es útil para el análisis de señales no estacionarias, debido a que para estos casos es necesario conocer la información contenida tanto en el dominio del tiempo, como en el de la frecuencia.

## 2.9. Transformada rápida de Fourier

La Transformada rápida de Fourier (FFT) está basada en el algoritmo de Cooley-Tukey, que tradicionalmente se ha utilizado en el procesamiento digital de señales. La FFT básicamente, es un algoritmo que tiene como objetivo calcular la DTFT de forma rápida y eficiente. Su importancia radica en que elimina una gran parte de los cálculos repetitivos que se pueden encontrar al momento de determinar una DTFT, logrando así, un mejor rendimiento en cuanto al tiempo de procesamiento de los cálculos (ya que utiliza una serie de atajos matemáticos) y un aumento de la precisión en el cálculo de la DTFT (por medio de la disminución de los errores de redondeo). La optimización de este algoritmo utiliza los siguientes conceptos [10]:

- Simetría y periodicidad de los términos  $\omega_k$ , que evitan operaciones redundantes de la DTFT.

- Se elige el valor de  $N$  de tal forma que  $N = r^m$ . El factor  $r$  se denomina *Factor Radix* y su valor más habitual es 2, tal que  $N = 2^m$ . Por lo tanto, el algoritmo se denomina FFT Radix-2.

## 2.10. Coeficientes cepstrales en la frecuencia Mel (MFCC)

Los coeficientes cepstrales en la frecuencia Mel, corresponden a una metodología para extraer características que proyecta las señales originales en otro espacio para reducir la dimensionalidad y posibilitar su modelamiento a partir de modelos probabilísticos. Están basados en una representación no lineal del sonido, pero con los coeficientes igualmente espaciados en la escala Mel, tal que, se realiza una aproximación más acertada de la respuesta del sistema auditivo humano, con respecto a los coeficientes cepstrales espaciados linealmente en la escala de frecuencia[19]. Para realizar el computo de los coeficientes MFCC se siguen los siguientes pasos [25]:

1. Se calcula la transformada discreta de Fourier por segmentos de cuasi-estacionariedad de las señales con la metodología explicada en la sección 2.9.
2. La potencia espectral de las señales, se pasa por un banco de filtros triangulares que están linealmente y no linealmente espaciados, de acuerdo con la aproximación de escalado en frecuencia Mel:

$$f_{mel} = 2595 * \log_{10}(1 + \frac{f}{700}) \quad (2.14)$$

3. Se calcula la transformada discreta del coseno (DCT) al logaritmo de la salida del banco de filtros, para obtener los coeficientes MFCC, como se muestra en la ecuación 2.15.

$$c(n) = \sum_{i=0}^{Q-1} S(i) * \cos(\frac{(\pi n(i - 0,5))}{Q}), 0 \leq n \leq Q - 1 \quad (2.15)$$

donde  $n$  es el número de coeficientes MFCC,  $Q$  es el número de filtros y  $S(i)$  es el logaritmo de la salida del banco de filtros.

## 2.11. Modelos Ocultos de Markov

Un modelo de Markov observable, puede ser descrito en todo momento a partir de un conjunto de  $N$  diferentes estados:  $Q_1, Q_2, \dots, Q_N$ . Por lo tanto, la salida del proceso estocástico es el conjunto de estados en cada instante de tiempo, donde cada estado corresponde a un evento físico (tirar una moneda o un dado) y las observaciones corresponden a al resultado de dicho lanzamiento [22].

Extendiendo el concepto explicado en el párrafo anterior, se incluye el caso en el cual las observaciones son una función probabilística del estado, así surgen los

Modelos ocultos de Markov que son procesos estocásticos doblemente embebidos, con un proceso estocástico subyacente que no es observable (está oculto), y solo puede ser observado, a partir de un conjunto de procesos estocásticos producidos por la secuencia de observaciones [14]. Donde las observaciones corresponden a características y los estados corresponden a conjuntos de características[21].

Cuando se habla de Modelos ocultos de Markov, se hace referencia también a las llamadas fuentes de Markov o funciones de probabilidad de una cadena de Markov. Se utiliza el criterio de optimización estándar (Máxima verosimilitud) para estimar los parámetros de un HMM, se asume que las secuencias de observaciones fueron generadas por fuentes de Markov y además, se desean diseñar varios modelos al tiempo, de tal forma que se maximice el poder de discriminación de cada modelo (habilidad de distinguir entre secuencias de observaciones generadas por un modelo correcto y otras secuencias generadas por modelos alternativos). El criterio utilizado consiste en separar las secuencias de observaciones de cada fuente  $\lambda_v$  en secuencias de entrenamiento  $O^v$  para obtener los parámetros de los modelos de forma independiente [22, 6].

Se ha incrementado el uso de estos modelos en diferentes campos, debido al profundo estudio y éxito obtenido en el campo del reconocimiento de voz. Principalmente estos modelos ofrecen:

- Una estructura matemática muy completa y, por lo tanto, pueden formar las bases teóricas para un amplio rango de aplicaciones, principalmente se destaca la clasificación de patrones, de señales con características de cuasi-estacionariedad.
- Cuando son aplicados adecuadamente, son muy acertados en la práctica para una gran cantidad de aplicaciones.

### 2.11.1. Notación básica Modelos Ocultos de Markov

-  $Q = Q_1, \dots, Q_N$ . Secuencia de posibles estados ocultos. Para aplicaciones prácticas, existe un significado físico ligado a los estados o grupos de estados.

-  $V = v_1, \dots, v_M$ . Conjunto de  $M$  posibles símbolos de observaciones externas.

-  $O = (O_1, \dots, O_T)$ . Secuencia de observaciones externas en  $T$  de instantes de tiempo.

-  $\lambda = (A, B, \pi)$ . Se define un modelo oculto de Markov por sus matrices  $A$ ,  $B$  y  $\pi$ .

-  $a_{ij} = P_\lambda(q_{t+1} = j | q_t = i)$ . Probabilidad de transición entre estados para el modelo  $\lambda$ .

-  $A = a_{ij}$ . Matriz de probabilidades de transición, de dimensión  $N \times N$

-  $b_j(k) = P_\lambda(o_t = k | q_t = j)$ . Probabilidad de emisión de un símbolo  $v_k$  en el estado  $Q_j$ .

-  $B = b_j(k)$ . Matriz de probabilidades de observaciones en el estado  $Q_j$ .

-  $\pi_i = P_\lambda(q_1 = i)$ . Probabilidad de estado inicial para el modelo  $\lambda$ .

-  $\pi = \pi_i$ . Es el vector de probabilidad de estados iniciales.

### 2.11.2. Notación para modelos de densidad continua

En muchas aplicaciones, el conjunto  $V$  es continuo, por lo tanto, en lugar de un matriz de probabilidad de símbolos  $B$ ; para cada estado  $q_i$ , existe una probabilidad de densidad de emisión para las observaciones en cada estado  $b(O/q_i)$ , donde  $O \in V$ . Esta probabilidad se modela como una distribución Gaussiana o una mezcla de ellas, por lo tanto, es necesario definir el vector de medias y la matriz de covarianzas que describen a la distribución, su notación es como sigue:

-  $\mu_{ik} = (\mu_{ik1}, \dots, \mu_{ikP})$ . Vector de medias de la mezcla de Gaussianas.

$$- \Sigma_{ik} = \begin{pmatrix} \sigma_{ik1}^2 & \sigma_{ik12} & \dots & \sigma_{ik1P} \\ \sigma_{ik21} & \sigma_{ik2}^2 & \dots & \sigma_{ik2P} \\ \dots & \dots & \dots & \dots \\ \sigma_{ikP1} & \sigma_{ikP2} & \dots & \sigma_{ikP}^2 \end{pmatrix}.$$

Matriz de covarianzas de la mezcla de Gaussianas de dimensiones  $P \times P$ .

Un modelo oculto de Markov continuo, produce secuencias de observaciones de la siguiente forma: En cada instante de tiempo el sistema genera un estado oculto denotado por  $q_t$ , de acuerdo con la distribución de probabilidad de transición entre estados  $a_{q_{t-1}, q_t}$ . Una vez el estado  $q_t$  ha sido generado, el sistema genera un *cluster* oculto  $m_t$ , de acuerdo con la distribución de probabilidad de emisión de estado a cluster  $g_{q_t, m_t}$ . Una vez el *cluster* oculto es determinado, un vector de observaciones es producido probabilísticamente, de acuerdo a la distribución de probabilidad de una mezcla de Gaussianas. Se puede pensar en los *cluster* como estados ocultos de bajo nivel, embebidos en un estado oculto  $q_t$  de alto nivel. Por ejemplo, los estados ocultos de alto nivel pueden representar fenómenos y los *cluster* ocultos de bajo nivel pueden representar categorías acústicas dentro del mismo fenómeno [17].

### 2.11.3. Problemas asociados a los modelos ocultos de Markov

Al emplear esta herramienta en cualquier tipo de aplicación, incluyendo el reconocimiento de patrones se presentan tres problemas fundamentales [22]:

1. **Problema de Evaluación:** dada una secuencia de observaciones externas  $O$ , y un modelo  $\lambda$ , como obtener eficientemente la probabilidad de una secuencia dado el modelo  $P(O/\lambda)$ ?

Este problema se resuelve mediante el algoritmo de avance-retroceso.

2. **Problema de decodificación:** dada una secuencia de observaciones externas  $O$ , y un modelo  $\lambda$ , como se elige la correspondiente secuencia de estados  $Q$ , que mejor explique las observaciones (secuencia de estados optima)?

Este problema se resuelve mediante el algoritmo de Viterbi, basado en métodos de programación dinámica.

3. **Problema de aprendizaje:** como optimizar los parámetros del modelo  $\lambda = (A, B, \pi)$ , tal que, se maximice  $P(O/\lambda)$ ?

Este último es el problema más importante en la mayoría de aplicaciones en las que se utilicen HMMs, dado que se quiere crear el modelo óptimo para representar el comportamiento de un fenómeno físico real.

Este problema se soluciona a partir de técnicas de optimización, en las cuales se realiza un procedimiento iterativo hasta que la función de costo llega a un mínimo local, entre los métodos empleados se encuentra el algoritmo de Baum-Welch y las técnicas de gradiente descendente.

Las herramientas utilizadas para solucionar cada uno de los problemas planteados, son obtenidas del *toolbox* desarrollado por Kevin Murphy en el departamento de ciencias de la computación en **The University of British Columbia**, disponible en [18], en este se encuentran implementados todos los algoritmos necesarios para trabajar con HMMs discretos y continuos, en forma de funciones para el software MATLAB.

#### 2.11.4. Criterio de información de Akaike

Se implementó el criterio de información de Akaike (AIC), el cual consiste en una medida relativa de la calidad de un modelo estadístico, en este caso de un modelo de Markov. Este criterio está fundado en teoría de la información y ofrece un estimado relativo de la información perdida cuando cierto modelo es usado para representar el proceso (obtención de los parámetros del modelo) que generó la secuencia de observaciones de entrenamiento, y al mismo tiempo, se encarga de la compensación *Trade-off* entre que tan bien se ajusta el modelo a los datos y la complejidad del modelo [1], esto resulta en penalizar la elección del modelo por un peso dado por  $A_n = 2$ .

Para calcular el valor AIC de un HMM, se utiliza la ecuación 2.16:

$$AIC(k) = \log(P(O|\widehat{\lambda}_k)) - \frac{N_k}{2} * (2) \quad (2.16)$$

Donde,  $\log(P(O|\widehat{\lambda}_k))$  es el logaritmo de la probabilidad de que la secuencia de observaciones  $O$ , haya sido generado por el modelo estimado  $\widehat{\lambda}_k$ .

Se define  $N_k$  como el número de parámetros libres que posee el modelo  $\widehat{\lambda}_k$ , y se define como:

$$N_k = N_k^A + N_k^B + N_k^\pi \quad (2.17)$$

donde:  $N_k^A = k(k-1)$  Es el número de parámetros libres de la matriz de probabilidad de transición.

$N_k^B = k*v + k*v$  Es el número de parámetros libres de la matriz de probabilidad de emisión, siendo  $v$  el número de diferentes símbolos en la observación.

$N_k^\pi = k - 1$  Es el número de parámetros libres del vector de probabilidad de transición del estado inicial.

### 2.11.5. Criterio de información Bayesiana

Se implementó el criterio de información Bayesiana (BIC), el cual se fundamenta en el teorema de Bayes para la selección del modelo, pero se asumen que las probabilidades iniciales (*Prior*) de todos los modelos son iguales, simplificando el teorema al llamado Factor de Bayes, que a su vez es aproximado hasta que se obtiene la expresión del criterio de información generalizada con un peso de penalización dado por  $A_n = \log(n)$ , donde  $n$  es el tamaño de las observaciones [9].

Para calcular el valor BIC de un HMM, se utiliza la ecuación 2.18:

$$BIC(k) = \log(P(O|\widehat{\lambda}_k)) - \frac{N_k}{2} * (\log(n)) \quad (2.18)$$

### 2.11.6. Criterio de longitud mínima de descripción de mezcla

Se implementó el criterio de longitud mínima de descripción de mezcla (MMDL), para HMMs. Se fundamenta en el caso de mezclas de Gaussianas, donde cada parámetro de la componente  $jth$  de la mezcla es penalizado por  $\log(nc_j)/2$ , donde  $c_j$  es la probabilidad de la componente  $jth$ , resultando en que  $nc_j$  puede ser visto como un "tamaño de muestra efectivo" para la componente  $jth$ . En [3], se describe la forma en la que se extrapola el concepto hasta que es posible aplicarlo en HMMs, para penalizar la complejidad del modelo.

Para calcular el valor MMDL de un HMM, se utiliza la ecuación 2.19:

$$MMDL(k) = \log(P(O|\widehat{\lambda}_k)) - \frac{k^2}{2} * (\log(n)) - \frac{v^2 + 3 * v}{4} * \sum_{m=1}^k \log(n * p_{\infty}(m)) \quad (2.19)$$

Donde  $p_{\infty}(m)$  es la probabilidad estacionaria para el estado  $m$  y  $v$  el número de diferentes símbolos en la observación.

# Capítulo 3

## Materiales y métodos

### 3.1. Base de datos de señales de vibraciones

Las bases de datos empleadas fueron suministradas por el grupo de investigación en Automática y se componen de: Case Western Reserve University Bearing Data Center y DB Bearing Diagnosis Rene de la Universidad Salesiana de Cuenca, Ecuador. Para el desarrollo de los algoritmos y su respectiva validación, se empleará la base de datos: DB Bearing Diagnosis Rene, debido a que se espera que represente un reto para el sistema de clasificación, debido a que en trabajos anteriores, el diagnóstico realizado sobre la base de datos de la universidad Western, se obtenía con un porcentaje de precisión muy alto, optando en algunos casos por introducir ruido blanco a las señales [12, 5], de esta forma se espera que los algoritmos se desarrollen con mayor generalidad y se compruebe la capacidad del clasificador de diferenciar entre clases que no son tan separables. Finalmente, con la base de datos: Case Western Reserve University Bearing, se realizarán trabajos de depuración y prueba de los algoritmos desarrollados.

En la base de datos: DB Bearing Diagnosis Rene, se emplearon rodamientos en estado normal y en otros tres diferentes estados, entre los cuales se encuentran: fallo en anillo interno, fallo en pista de rodadura exterior y fallo en elemento rodante. Teniendo en cuenta el esquema de obtención presente en la figura 3.1, se realizaron combinaciones por pares de los rodamientos en los diferentes estados y se obtuvieron siete patrones de estas combinaciones. En los anexos se encuentra el detallado del esquema de obtención de la base de datos con la que se realizó el trabajo.

#### 3.1.1. Base de datos de la Universidad Salesiana de Cuenca

En esta parte se describirán las condiciones bajo las cuales se recopilaron las señales de la base de datos, sus patrones de falla y, por último, el conjunto de datos que determina la cantidad de clases presentes en los registros [15].



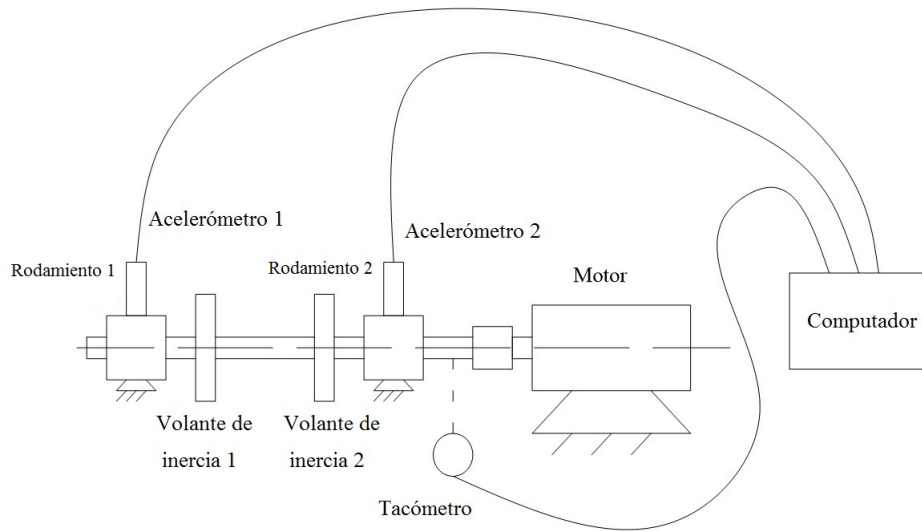


Figura 3.1: Esquema de obtención de las señales de vibración mecánicas de rodamientos.

*Condiciones de recopilación:*

- Frecuencia de muestreo: 50kHz (Para cada acelerómetro), 1 pulso/rev (Para el tacómetro).
- Tamaño de las muestras: 20 Seg.
- Repetición de los experimentos: 5 veces por cada experimento (R1, R2, ... , R5).
- Velocidad de rotación: 8Hz (F1), 10Hz (F2), 15Hz (F3).
- Carga: Sin volante de inercia (L1), 1 volante de inercia (L2), 2 volantes de inercia (L3).

*Patrones de falla de los rodamientos para la recopilación:*

**P1** Normal 1, normal 2 (H1H2).

**P2** Fallo en anillo interno 1, normal 2 (I1H2).

**P3** Fallo en pista de rodadura exterior 1, normal 2 (O1H2).

**P4** Fallo en elemento rodante 1, normal 2 (B1H2).

**P5** Fallo en anillo interno 1, fallo en pista de rodadura exterior 2 (I1O2).

**P6** Fallo en anillo interno 1, fallo en elemento rodante 2 (I1B2).

**P7** Fallo en pista de rodadura exterior 1, fallo en elemento rodante 2 (O1B2)

*Conjunto de datos:*

Tabla 3.1: Conjunto de datos

Canal	Repetición	Frecuencia	Carga	Fallas
A1	R1	F1	L1	P1
A2	R2	F2	L2	P2
T1	R3	F3	L3	P3
	R4			P4
	R5			P5
				P6
				P7

### 3.1.2. Base de datos de la universidad Western Reserve

En esta parte se describirán las condiciones bajo las cuales se recopilaban las señales de la base de datos, sus tipos de falla y, por último, el conjunto de datos que determina la cantidad de clases presentes en los registros. Esta base de datos está abierta al público y puede ser obtenida desde la página de la universidad Western Reserve en [8].

En este caso se utilizó un motor monofásico de 2 HP y los registros fueron obtenidos a partir de un acelerómetro y un tacómetro, ubicados sobre el rodamiento y en el eje del motor respectivamente. Se presentan los tipos de fallas inducidos a partir del método de mecanizado por electro-descarga (EMD), tal que se obtienen diferentes grados de degradación en los defectos de los rodamientos.

*Condiciones de recopilación:*

- Número de balineras: 9.
- Diámetro de cada balinera: 0.3126 pulgadas.
- Frecuencia de muestreo: 48 kHz (un acelerómetro).
- Tamaño de las muestras: variante.
- Repetición de los experimentos: 4 veces por cada experimento (R1, R2, R3, R4).
- Velocidad de rotación: 1797 rpm (V1), 1772 rpm (V2), 1750 rpm (V3), 1730 rpm (V4).
- Carga: Sin volante de inercia (L1), 1 volante de inercia (L2), 2 volantes de inercia (L3), 3 volantes de inercia (L4).

*Tipos de falla en los rodamientos:*

**Inner** Fallo en anillo interno.

**Ball** Fallo en elemento rodante.

**Outer** Fallo en pista de rodadura exterior 1.

*Conjunto de datos:*

Tabla 3.2: Conjunto de registros de la base de datos.

Estado	Degradación	Carga	Velocidad	Registro Falla (Inner)	Registro Falla (Ball)	Registro Falla (Outer)
Falla	0.007 pulgadas	L1	V1	109	122	135
		L2	V2	110	123	136
		L3	V3	111	124	137
		L4	V4	112	125	138
	0.014 pulgadas	L1	V1	173	189	201
		L2	V2	175	190	202
		L3	V3	176	191	203
		L4	V4	177	192	204
	0.021 pulgadas	L1	V1	213	226	238
		L2	V2	214	227	239
		L3	V3	215	228	240
		L4	V4	217	229	241

### 3.1.3. Método para realizar el pre-procesamiento

La etapa de pre-procesamiento surge a partir de la necesidad encontrada en el estado del arte de segmentar y acondicionar la señal de vibración, tal que se extraiga de ella la mayor cantidad de información del estado de la máquina.

Se desarrolló un algoritmo para obtener el trozo óptimo de la señal de vibración, a partir del cual, la precisión de un clasificador sencillo tienda a mantenerse constante, tal que, el fenómeno del fallo en la señal de vibración este completamente descrito, sin embargo, también es deseado que la aplicación desarrollada sea computacionalmente eficiente. Se ha comprobado que el tiempo de cómputo y los requerimientos de memoria tienden a incrementarse ante el aumento del tamaño del trozo, por lo tanto, el segmento óptimo se debe elegir teniendo en cuenta todos los criterios mencionados.

El algoritmo planteado se describe en los siguientes pasos:

1. Inicialmente se cargan las señales de vibración provenientes de los rodamientos de un motor en los diferentes estados de salud (normal, fallo en pista de rodadura exterior, fallo en anillo interno o fallo en elemento rodante). Cada señal es de 20 segundos de duración muestreada a una frecuencia de  $50KHz$ , por efectos prácticos se toman 4 segundos de la señal a partir de la mitad de cada registro, resultando en un total de 200 mil puntos discretos.
2. Se definen los diferentes tamaños de segmento a evaluar.

3. Se segmentan todas las señales del acelerómetro 1, en los diferentes segmentos definidos.
4. Se realiza la caracterización en tiempo-frecuencia de las señales segmentadas con cada uno de los tamaños definidos, empleando la transformada wavelet discreta, con Wavelet madre Daubechies 4, Coiflets 2, Daubechies 2 y Haar. Se extrajo el conjunto de descriptores estadísticos de la sección 2.3, a los coeficientes de detalle obtenidos, los cuales fueron concatenados de acuerdo a la Wavelet madre empleada.
5. Finalmente, se entrena el clasificador de la sección 2.4 con las características obtenidas de las señales segmentadas y se almacena la precisión del clasificador para cada iteración (tamaño del segmento). Finalmente se obtiene una gráfica de precisión en función de los diferentes tamaños de segmento.

### 3.2. Método para realizar el Test de estacionariedad

Para que una serie sea estacionaria,  $f_x[n]$  no debe variar con  $n$ . En particular, la media y la varianza no deben variar con  $n$  [23].

Para determinar si esto es cierto se sigue el siguiente procedimiento:

- Dividir la señal en dos o más trozos secuenciales, y calcular la media muestral y la varianza muestral de cada trozo.
- Las medias muestrales deben ser comparadas informalmente mediante un gráfico o deben ser puestas a prueba formalmente en busca de un cambio utilizando el test descrito en la sección 2.5.
- Las varianzas muestrales deben ser comparadas informalmente mediante un gráfico o deben ser puestas a prueba formalmente en busca de un cambio utilizando el test descrito en en la sección 2.6.

### 3.3. Método de extracción de características de ventaneo en frecuencia

Se implementó el siguiente esquema de extracción de características para posteriormente entrenar y validar el sistema de clasificación:

1. Se concatenan cada uno de los segmentos obtenidos, tal que las filas sean los diferentes segmentos y las columnas correspondan a la amplitud de las señales de vibración.
2. A cada segmento por separado se le calcula el espectro de Fourier, a partir de la transformada descrita en la sección 2.9.

3. El espectro de cada señal es dividido en 40 bandas de frecuencia, y sobre cada banda se calcula el conjunto de descriptores estadísticos, sección 2.3.

### 3.4. Método para la extracción de los coeficientes MFCC

Se implementó el siguiente esquema de extracción de características para posteriormente entrenar y validar el sistema de clasificación:

1. Se concatenan cada uno de los segmentos obtenidos, tal que las filas sean los diferentes segmentos y las columnas correspondan a la amplitud de las señales de vibración.
2. A cada segmento se le calculan los coeficientes cepstrales en la frecuencia Mel, con el computo descrito en la sección 2.10.

### 3.5. Método secuencial de poda de estados

Uno de los problemas fundamentales al emplear modelos ocultos de Markov en aplicaciones reales es la de determinar el número de estados suficiente para describir los fenómenos presentes en las señales a analizar, en [3] se propone la Estrategia secuencial de poda de estados, que consiste en:

1. Definir los criterios de selección de modelos a utilizar, definidos en las secciones 2.11.4, 2.11.5 y 2.11.6; Establecer aleatoriamente  $k_{min}$  y  $k_{max}$  que corresponden al número mínimo y máximo de estados permitidos.
2. Inicializar el algoritmo de estimación de parámetros de un HMM utilizando  $k_{max}$  estados,  $\lambda_k^I$  representa el modelo inicial del procedimiento con  $k$  estados.
3. Mientras  $k \leq k_{min}$ :
  - a) Optimizar los parámetros del modelo utilizando el algoritmo de Baum-Welch,  $\widehat{\lambda}_k$ .
  - b) Calcular y almacenar el valor obtenido al aplicar el criterio de selección de modelo con los parámetros optimizados.
  - c) Encontrar el estado menos probable ( $P_\infty$  más pequeño).
  - d) Eliminar o podar el estado menos probable, eliminando los elementos  $A, B$  y de esta forma, obtener un modelo reducido,  $\bar{\lambda}$ .
  - e) Actualizar los valores iniciales así:
 
$$\lambda_k^I \leftarrow \bar{\lambda} \text{ y } k \leftarrow k - 1.$$
4. Finalmente, el modelo escogido  $\lambda^*$ , es el que tiene el mayor valor al calcular el criterio de selección.

En [9], recomiendan utilizar los criterios AIC y BIC en conjunto para la selección del modelo, debido a que el AIC siempre presenta la posibilidad de elegir un modelo demasiado grande y el BIC presenta la posibilidad de elegir un modelo demasiado pequeño debido a que este criterio penaliza duramente la complejidad del modelo.

### 3.6. Método de clasificación por capas

Se plantea una alternativa para realizar la clasificación de señales de vibración, la cual consiste en disminuir el número de modelos a entrenar, al realizar una clasificación basada en la regla de decisión de Bayes, por capas o instancias. Inicialmente en la primera capa, se realiza la clasificación de las señales de vibración en HMMs que modelan las dinámicas de los patrones de falla presentes en la base de datos y se realiza su correspondiente validación estadística. Finalmente, en la segunda capa, se realiza la clasificación de las señales de vibración en HMMs entrenados para representar las diferentes condiciones operacionales que se presentan en la base de datos y se realiza su correspondiente validación estadística. Este método se presenta con el fin de disminuir el tiempo de cómputo y aprovechar al máximo la herramienta de reconocimiento de patrones implementada.

El algoritmo que se debe implementar se presenta a continuación:

1. Se realiza la extracción de características de señales de vibración en segmentos de cuasi-estacionariedad.
2. Se utiliza el número de estados obtenido en el algoritmo de poda de estados, como parámetro libre para generar los HMMs.
3. Se entrenan tantos modelos como tipos de falla existan, estos modelos se entrenan con señales de todas las condiciones operacionales.
4. Se valida estadísticamente el sistema de clasificación de fallas, basado en la regla de decisión de Bayes.
5. Se entrenan tantos modelos como condiciones operacionales existan, estos modelos se entrenan con señales de todos los tipos de falla.
6. Se valida estadísticamente el sistema de clasificación de condiciones operacionales, basado en la regla de decisión de Bayes.

# Capítulo 4

## Implementación y validación de resultados

### 4.1. Pre-procesamiento

En esta sección se presenta el resultado obtenido al emplear el método planteado en la sección 3.1.3 para realizar el pre-procesamiento de las señales de vibración, en figura 4.1, se observa la curva de aprendizaje del clasificador a través de diferentes tamaños de segmento:




Figura 4.1: Precisión del clasificador en función del tamaño de segmento.

El segmento óptimo es elegido a partir de la precisión del sistema de clasificación basado en KNN, y teniendo en cuenta que el tiempo de cómputo y los requerimientos de memoria tienden a incrementarse ante el aumento del tamaño del trozo, por lo tanto, el segmento óptimo es el de 4096 puntos. Se observa también, que el

clasificador KNN presenta limitaciones al clasificar entre las 63 clases originales.

## 4.2. Resultado de evaluar la cuasi-estacionariedad de señales de vibración

Una vez obtenido el segmento óptimo, se puso a prueba el algoritmo para evaluar la cuasi-estacionariedad de las señales de vibración, descrito en la sección 3.2. El desarrollo que se requirió adicional consistía en la adecuación de las señales de vibración, tal que estas fuesen segmentadas y organizadas por conjuntos, con la intención de que se empleara el test sobre todos los segmentos asociados a una determinada señal, evitando sesgos y pérdidas de información.

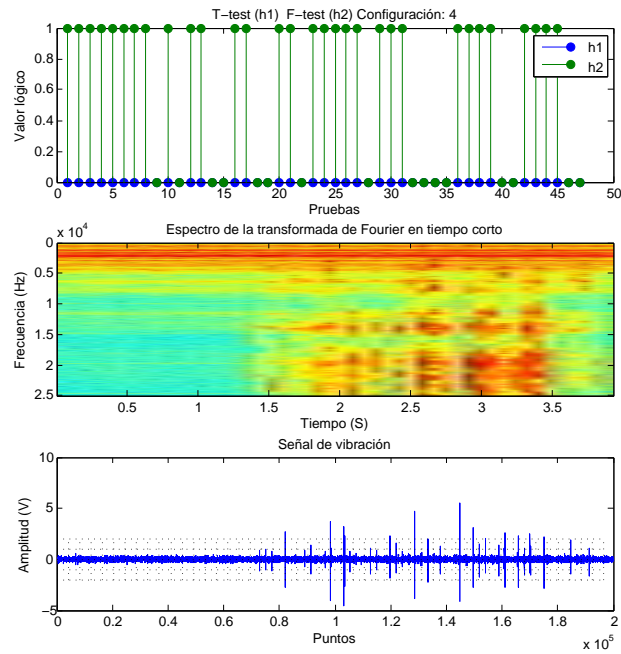
Es necesario retomar la conformación de la base de datos para una explicación más detallada.

La base de datos utilizada se compone de 315 señales, de las cuales existen 63 señales originales y 5 repeticiones de cada una, dentro de estas 63 señales originales, existe una secuencia de 9 condiciones operacionales (carga y velocidad) que se repite para 7 configuraciones de pares de rodamientos en diferentes estados. Por lo tanto, si se desea comparar señales de esta base de datos mediante un test estadístico para encontrar patrones dadas las diferentes configuraciones de rodamientos, esta comparación debería hacerse para la misma repetición y la misma condición operacional.


Los test se realizaron sobre segmentos subyacentes, empezando sobre los primeros dos segmentos, luego sobre el segundo y el tercero. Y así sucesivamente hasta la totalidad de segmentos de señal. Por efectos prácticos, se limitaron las señales a una duración de 4 segundos a partir de la mitad de cada señal, resultando en 48 segmentos de 4096 puntos por cada señal, para un total de 15120 segmentos de la base de datos. Por cada señal, se plantearon 47 pruebas de las 2 hipótesis planteadas, generando finalmente para toda la base de datos un total de 14805 pruebas.

En la figura 4.2, se muestra un ejemplo del algoritmo para evaluar la estacionariedad de una señal.





(a) Señal: configuración 4, repetición 4, sin carga, velocidad 8 Hz.



(b) Señal: configuración 1, repetición 4, sin carga, velocidad 8 Hz.

Figura 4.2: Resultado del algoritmo para evaluar estacionariedad

En la figura 4.2a, se realiza el test de estacionariedad a una señal de la base de datos, esta señal es estacionaria en media,  $h1$  no se rechaza (0 lógico) entre segmentos de la señal y altamente no-estacionaria en varianza,  $h2$  se rechaza (1 lógico) entre segmentos de la señal. Lo cual quiere decir que la serie de datos correspondiente a esta señal es estacionaria en media y no estacionaria en varianza. Es posible observar que la energía de esta señal está distribuida de forma no uniforme a través del espectrograma y que la señal como tal presenta grandes cambios entre segmentos.

En la figura 4.2b, representa una señal estacionaria en media y altamente no estacionaria en varianza, sin embargo, a través del espectrograma se nota que la energía de esta se distribuye de forma más uniforme con respecto a la energía representada en la figura 4.2a y la señal como tal es visiblemente igual entre segmentos.

A continuación, se realizó una prueba que consistía en contabilizar la cantidad de veces que se rechazaba la hipótesis que ponía a prueba la estacionariedad en varianza de las señales. Esta prueba se hizo con el fin de obtener información sobre la incidencia que tienen las diferentes configuraciones de rodamientos sobre la estacionariedad de las señales, los resultados para una misma repetición se muestran en la siguiente tabla.

Tabla 4.1: Cantidad de veces que se rechaza la hipótesis de estacionariedad en varianza

Repetición 4		Configuración de rodamientos						
		1	2	3	4	5	6	7
Condición operacional	1	28/47	33/47	31/47	31/47	34/47	37/47	38/47
	2	34/47	36/47	21/47	33/47	33/47	34/47	38/47
	3	35/47	36/47	28/47	27/47	36/47	46/47	32/47
	4	24/47	28/47	36/47	25/47	39/47	40/47	39/47
	5	19/47	31/47	34/47	19/47	38/47	40/47	41/47
	6	18/47	31/47	38/47	26/47	39/47	32/47	36/47
	7	28/47	29/47	37/47	28/47	37/47	43/47	40/47
	8	17/47	30/47	25/47	34/47	34/47	40/47	37/47
	9	36/47	32/47	33/47	38/47	37/47	43/47	36/47
Total		239/423	286/423	283/423	261/423	327/423	355/423	337/423

En la tabla 4.1 se observa cómo se afecta la estacionariedad en varianza dadas las diferentes configuraciones de rodamientos a través de las diferentes condiciones operacionales. Esta tabla se realizó para otras repeticiones, sin embargo, se notó que siempre la configuración más estacionaria en varianza ante los cambios en la operación es la 1, correspondiente a dos rodamientos en estado normal. Por el contrario, la menos estacionaria es la configuración 6, correspondiente al primer rodamiento con fallo en anillo interno y el segundo con fallo en elemento rodante. Para las demás configuraciones la tendencia entre una repetición y otra no es tan evidente.


Al realizar las pruebas se puede concluir que las señales vibración generadas por máquinas rotativas son procesos estocásticos, que tienen componentes variando de forma no-periódica e independiente con respecto al tiempo, debido a que los test estadísticos aplicados a señales iguales, pero de diferente repetición cambian sensiblemente. Por lo tanto, se corrobora una hipótesis que se ha planteado y aceptado

en el estado del arte [24]. Además del seguimiento a los resultados del test, se realizó un espectrograma (representación en un plano tiempo-frecuencia) de la señal, para observar como la energía contenida en esta cambia de acuerdo a los resultados del test. Al realizar las pruebas se nota que la mayor cantidad de energía en las señales se encuentra representada por debajo de los 20 KHz, con excepción de las señales de la configuración de rodamientos número 4 (primer rodamiento con fallo en bola y segundo rodamiento normal) que si tiene energía esparcida por toda la banda de frecuencia.


### 4.3. Estrategia de la poda de estados

Para implementar el algoritmo planteado en la sección 3.5, se definieron las observaciones a partir de las características obtenidas en las secciones 3.4 y 3.3. En términos de los modelos ocultos de Markov, cada segmento es una secuencia, los coeficientes MFCC o los descriptores estadísticos son los diferentes símbolos de observaciones  $V$ , siendo las observaciones la evolución de los símbolos de observaciones a través del tiempo, en este caso ventanas de frecuencia. Resultando en una matriz  $P^{V \times T \times N}$ , donde  $V$  es el conjunto de coeficientes MFCC o descriptores estadísticos,  $T$  son las ventanas de frecuencia y  $N$  los diferentes segmentos [3].


Este método determina la cantidad de estados necesarios para definir la dinámica intrínseca de las señales de vibraciones mecánicas, en los diferentes estados de salud de los rodamientos y en las diferentes condiciones operacionales, que de igual forma afectan el comportamiento de dichas señales. Se evaluó el algoritmo para 20 secuencias por clase, resultando en un total de 1260 secuencias. Una vez obtenido el número de estados óptimo para cada una de las secuencias, se gráfica el histograma de los resultados para cada clase. Finalmente se define como el número de estados óptimo el número de estados que mayor cantidad de secuencias, independiente de la clase, obtenga. En la figura 4.4, se muestra el histograma que define el número de estados óptimo para los diferentes criterios (AIC, BIC, MMDL).



(a) Resultados del número de estados óptimo empleando el criterio de Información de Akaike (AIC).




(b) Resultados del número de estados óptimo empleando el criterio de Información Bayesiana (BIC).




(c) Resultados del número de estados óptimo empleando el criterio de longitud mínima de descripción de mezcla (MMDL).


Figura 4.3: Histogramas de los resultados obtenidos al aplicar la estrategia de la poda, empleando diferentes criterios y observaciones de ventaneo en frecuencia.



(a) Resultados del número de estados óptimo empleando el criterio de Información de Akaike (AIC).



(b) Resultados del número de estados óptimo empleando el criterio de Información Bayesiana (BIC).



(c) Resultados del número de estados óptimo empleando el criterio de longitud mínima de descripción de mezcla (MMDL).

Figura 4.4: Histogramas de los resultados obtenidos al aplicar la estrategia de la poda, empleando diferentes criterios y observaciones de coeficientes MFCC.

En ambos casos mediante los criterios AIC y BIC, se obtiene que el número de estados óptimo es 2. Por otro lado, al emplear el criterio de longitud mínima de descripción de mezcla (MMDL), cambia sensiblemente entre características, como se observa en la figura 4.4c y 4.3c. De acuerdo con lo planteado en [3], se debe tener en cuenta el resultado de todos los criterios debido a que no existe una superioridad evidente entre estos.

## 4.4. Validación de resultados

Se realizó un algoritmo para estimar un modelo oculto de Markov para cada una de las clases de la base de datos, que corresponden las diferentes combinaciones de pares de rodamientos y condiciones operacionales, en total 63 clases. Cada uno de los segmentos obtenidos en la sección 4.1, se identificó con una etiqueta correspondiente a la clase a la cual pertenecía. Se utilizó el método de *K-folds*, para dividir las señales en conjuntos de entrenamiento y validación de forma balanceada.

Para la estimación de los parámetros de los HMMs, se utilizaron las señales dispuestas para el entrenamiento. En total se generaron por cada *fold* tantos modelos como clases existieran, para generar estos modelos se utilizó la función *mhmm-em* del *Toolbox* para estimar los parámetros de un HMM diseñado Kevin Murphy, disponible en [18].

Para obtener el número de parámetros libres de los HMM, se utilizó la validación cruzada anidada, en la cual se tiene una validación cruzada interna que permite elegir los parámetros libres de forma manual, tal que el modelo ganador se obtiene a partir de la mayor probabilidad  $\log(P(O|\hat{\lambda}_k))$ , sin importar la complejidad del modelo. Por otro lado, se tiene una validación cruzada superior, en la que se define la medida de rendimiento del clasificador, utilizando el acierto al comparar entre las etiquetas generadas por el clasificador para las señales de validación y las esperadas según la clase a la que pertenecen dichas señales.

Dado un modelo generado a partir de las señales de entrenamiento y buscando maximizar  $P(\lambda_v|o^v)$  mediante el algoritmo de optimización de Baum-Welch, se emplea la regla de decisión de Bayes para evaluar la probabilidad de que una secuencia de observaciones pertenezca a un modelo dado, es decir  $\max(P(o^v|\lambda_{1,2,\dots,v}))$ . Dicha probabilidad se obtiene mediante la función *mhmm-logprob*, que hace parte del *toolbox* de Murphy.

### 4.4.1. Validación cruzada

La significancia estadística del sistema de clasificación implementado se evaluó a partir de utilizar validación cruzada junto con el método de *k-folds*. En cada iteración (*fold*) del algoritmo se genera un porcentaje de acierto del clasificador, correspondiente a la cantidad de aciertos obtenidos al comparar las etiquetas estimadas por el clasificador y las etiquetas reales de cada secuencia, al iterar 10 veces (10 *folds*), se obtienen 10 resultados del porcentaje de acierto, a partir de los cuales, se obtiene la media y la desviación estándar del acierto del clasificador.

A partir del número de estados óptimos obtenidos de la sección 4.3, se fijaron los parámetros libres del sistema de clasificación y simplemente se buscaba determinar a partir de validación cruzada, que conjunto de observaciones  $V$  permitía que los modelos ocultos de Markov representaran mejor las dinámicas intrínsecas de las señales, tal que, la clasificación de señales de prueba se realizara con mayor precisión.

Se llevaron a cabo 2 validaciones con tipos de características diferentes, la primera corresponde a utilizar las características obtenidas en la sección 3.3 como el conjunto de observaciones para hacer el entrenamiento y validación del sistema de clasificación implementado, el resultado de esta clasificación se muestra en la tabla 4.2.

Tabla 4.2: Resultados de las pruebas realizadas con número de estados óptimos para las observaciones del ventaneo en frecuencia.

Número de estados	Media $\pm$ Desviación Estándar
2 estados	56,81 $\pm$ 2,02
10 estados	91,57 $\pm$ 1,35

La segunda validación cruzada corresponde a utilizar los coeficientes cepstrales en frecuencia Mel obtenidos en la sección 3.4, como el conjunto de observaciones para hacer el entrenamiento y validación del sistema de clasificación implementado, el resultado de esta clasificación se muestra en la tabla 4.3.

Tabla 4.3: Resultados de las pruebas realizadas con número de estados óptimos para las observaciones de coeficientes MFCC.

Número de estados	Media $\pm$ Desviación Estándar
2 estados	98,21 $\pm$ 0,58
7 estados	98,00 $\pm$ 0,48

Se observa que el espacio de representación que mejor rendimiento genera en la clasificación de señales de vibraciones mecánicas de máquinas rotativas es el de coeficientes cepstrales en frecuencia Mel, por lo tanto, se establece esta representación como la más adecuada para este tipo de señales.

Se determina, además, el tipo de característica empleada como observación, cumple un papel fundamental en la correcta operación del sistema de clasificación implementado, debido a que como se observa en la tabla 4.2, el sistema tiende a mejorar la clasificación si se aumentan el número de estados, situación indeseada si se tiene en cuenta la carga computacional que esto supone. Se deduce, que el sistema diverge al no tener las características adecuadas, para una correcta interpretación de las dinámicas presentes en las señales y tratando de solucionar este inconveniente incrementando el número de estados de forma indefinida.

Caso contrario se presenta en 4.3, donde el sistema de clasificación tiende a mantener constante su acierto, ante ambos resultados obtenidos al aplicar el criterio de la poda, lo que supone que el sistema de clasificación converge, al ser entrenado con observaciones adecuadas para una correcta interpretación de las dinámicas

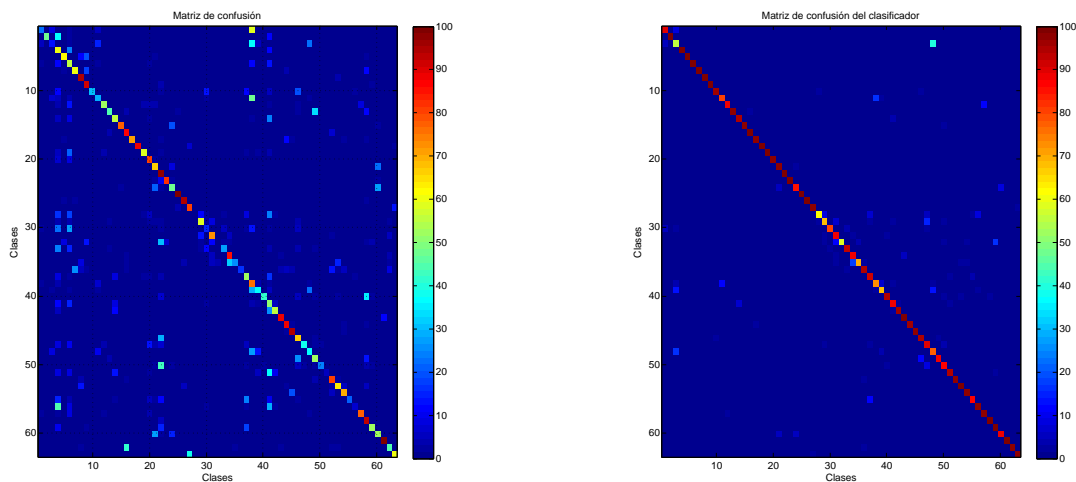
intrínsecas de las señales, manteniéndose robusto así el número de estados no sea el óptimo.

Resulta evidente que el tipo de característica al emplear HMMs es fundamental, pues puede generar que el sistema se vuelva mucho más complejo y costoso computacionalmente, si las características no son adecuadas.

#### **4.4.2. Matriz de confusión**

La significancia estadística del sistema de clasificación implementado se evaluó a partir de utilizar matrices de confusión, en las cuales se registra el porcentaje de correspondencia de las etiquetas estimadas por el clasificador, con las etiquetas reales de cada clase. En cada caso se realizó un promedio de las matrices de confusión de los 10 *folds* utilizados, tal que, se observara en la matriz general el efecto de las posibles confusiones del sistema de clasificación, resaltando las tendencias más evidentes. En las figuras 4.5 y 4.6, se muestran las matrices de confusión del sistema de clasificación implementado, para características de ventaneo en frecuencia y coeficientes MFCC.






(a) Matriz de confusión del sistema de clasificación con 2 estados.

(b) Matriz de confusión del sistema de clasificación con 10 estados.

Figura 4.5: Matriz de confusión del sistema de clasificación para las observaciones de ventaneo en frecuencia.



(a) Matriz de confusión del sistema de clasificación con 2 estados.

(b) Matriz de confusión del sistema de clasificación con 7 estados.

Figura 4.6: Matriz de confusión del sistema de clasificación para las observaciones de coeficientes MFCC.

Se observa en las figuras 4.6 y 4.5, las clases con las que el sistema tiene confusión. Particularmente, se observa que la figura 4.5a es en la que mayor confusión se presenta, en general esto ocurre debido a que el sistema no cuenta con las características adecuadas para realizar la clasificación y el número de estados que tiene es muy bajo para tratar de contrarrestar este problema. Sin embargo, tratar de corregir el problema adicionando más estados no es conveniente, debido a que, de esta forma la complejidad del sistema va a aumentar y de igual forma, no se obtendrá un resultado satisfactorio, teniendo en cuenta que, con pocos estados y una característica adecuada se presenta la matriz de la figura 4.6a, con muy poca confusión.

### 4.4.3. Validación cruzada anidada

La validación cruzada anidada es utilizada para obtener de forma manual el número de estados óptimos del sistema de clasificación de datos de acuerdo a su poder discriminaste (presión al realizar la clasificación) y sin tener en cuenta la complejidad del modelo. De esta forma, Se busca comprobar la veracidad del algoritmo de poda de estados para la elección del mejor modelo. En la figura 4.7, se observa la curva promedio de entrenamiento del clasificador, esta es resultado de utilizar el algoritmo de validación cruzada anidada en todos los *folds* y promediar sus respectivas curvas de entrenamiento.




Figura 4.7: Curva de entrenamiento del sistema de clasificación

Como se observa, el sistema a partir de 2 estados empieza a caer en cuanto a la precisión con la que clasifica las diferentes señales. Según los criterios AIC y BIC,

el número de estados óptimo es 2, lo que corresponde a la mayor precisión obtenida al clasificar las señales. Finalmente se comprueba que estos dos criterios generaron automáticamente el número de estados óptimo, comprobado a partir utilizar validación cruzada anidada. Con respecto al criterio MMDL, se nota que tiende a elegir modelos demasiado complejos que resultan costosos computacionalmente.

A continuación, se tabularon los resultados de las pruebas realizada para 10 *fold*s y utilizando las observaciones generadas a partir de coeficientes MFCC. Finalmente, en la tabla 4.4 se presenta el acierto del sistema de clasificación aplicando el algoritmo de validación cruzada anidada, con el número de estados obtenido del promedio del resultante para cada *fold*. En la figura 4.8 se presenta su correspondiente matriz de confusión.

Tabla 4.4: Resultado del algoritmo con validación cruzada anidada.

Número de estados	Media $\pm$ Desviación Estándar
2,80 $\pm$ 1,03	98,40 $\pm$ 0,57




Figura 4.8: Matriz de confusión del sistema de clasificación empleando validación cruzada anidada.

Se comprueba a partir del algoritmo de validación cruzada anidada, que el acierto del sistema de clasificación es óptimo en cuanto a precisión y tiempo de computo,

cuando se utiliza el número de estados obtenidos a partir de criterios de teoría de la información. Resultando, en que los criterios AIC y BIC son los mejores criterios para la selección de modelos, cuando se están obteniendo modelos ocultos de Markov de señales de vibraciones mecánicas de máquinas rotativas.

Varios autores [9, 1, 17] plantean que el modelo que genera mayor verosimilitud tiende a ser aquel con mayor número de estados, sin embargo, como queda demostrado en este trabajo, esta afirmación solo se cumple si, las características no son lo suficientemente representativas, para que el clasificador reconozca las dinámicas intrínsecas y converja. Teniendo que aumentar el número de estados, en busca de una mejor aproximación, en la cual es válido afirmar que diverge y además aumenta considerablemente el tiempo de computo.

## 4.5. Modelos Ocultos de Markov por capas

Este método se presenta con el fin de disminuir el tiempo de cómputo y aprovechar al máximo la herramienta de reconocimiento de patrones implementada, ya se demostró lo robusto que resulta implementar HMMs para realizar el diagnostico de fallas y la identificación de condiciones operacionales de forma automática, y como con un porcentaje de acierto muy alto, discrimina entre muchas dinámicas diferentes, ahora se quiere comprobar a partir de esta alternativa, si se puede mantener un porcentaje de clasificación alto, a la vez que se reduce el tiempo de computo al disminuir el número de modelos que se deben entrenar.

Inicialmente, se generaron HMMs para cada clase de la base de datos, esto correspondía a generar 63 modelos. Las correspondientes clases se obtenían al tener 7 patrones de fallas diferentes en los rodamientos, a los cuales se les realizaba diferentes combinaciones de velocidad y carga, resultando en un total de 9 experimentos, sección 3.1.1. Al realizar la clasificación por capas, se quiere determinar en una primera clasificación el patrón de falla, y a continuación, en otra clasificación la condición operacional. Finalmente, se entrenarán por lo tanto 16 modelos, muchos menos que los entrenados inicialmente para realizar la misma clasificación, el resultado se presenta a continuación.

Tabla 4.5: Resultado de la validación cruzada para determinar el tipo de patrón de falla (Capa 1).

Número de estados	Media $\pm$ Desviación Estándar
2	97,78 $\pm$ 0,99

Tabla 4.6: Resultado de la validación cruzada para determinar el tipo de condición operacional (Capa 2).

Número de estados	Media $\pm$ Desviación Estándar
2	90,70 $\pm$ 2,21

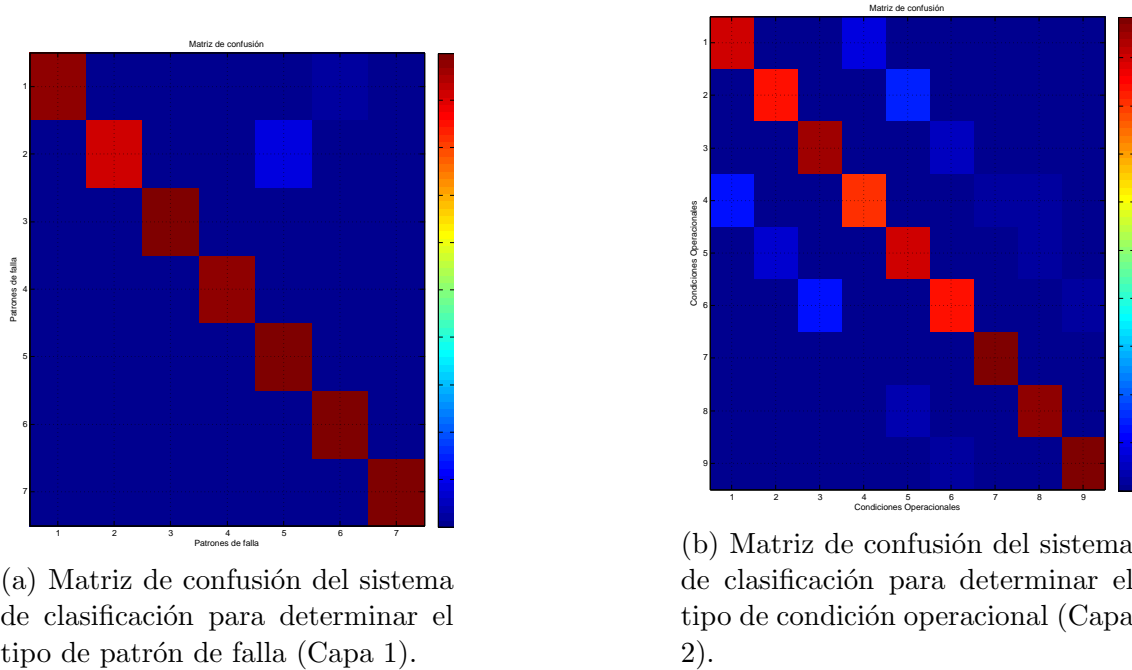


Figura 4.9: Matriz de confusión del sistema de clasificación por capas.

Al realizar el experimento, se observa que el sistema de clasificación mantiene un alto porcentaje de precisión al clasificar los patrones de falla, sin embargo, cae sensiblemente la precisión al clasificar las condiciones operacionales. mientras que el tiempo de computo se reduce en gran medida, dado que el sistema no debe entrenar tantos modelos en cada iteración. Por lo tanto, Se establece que realizar una clasificación por capas es computacionalmente más eficiente, pero el sistema de clasificación no es tan preciso como en la otra configuración.

## 4.6. Resultados obtenidos al emplear la base de datos de la universidad Western Reserve

En esta sección se plantea comprobar los algoritmos implementados y corroborar que los resultados obtenidos son aplicables para señales de vibración indistintamente de la base de datos. Utilizando una base de datos diferente a la empleada inicialmente para desarrollarlos, se pretende demostrar la generalidad del sistema de clasificación de señales implementado. La diferencia principal entre las bases de datos utilizadas radica en que para la base de datos de la universidad Salesiana de Cuenca, a cada tipo de falla se le realizaron pruebas con diferentes configuraciones de velocidad y carga. Por otro parte, en la base de datos de la universidad Western reserve, cada tipo de fallo tiene 3 niveles de degradación diferentes como se muestra en la tabla 3.2, esto resulta en una menor cantidad de clases. A continuación, se presentan los resultados de emplear los algoritmos desarrollados para clasificar señales de vibración de rodamientos con falla y diferentes grados de degradación.

Se dividieron las señales de vibración en segmentos de cuasi-estacionaridad, se empleó el tamaño de segmento previamente obtenido. Seguidamente, se extrajo de cada segmento los coeficientes MFCC con la metodología de la sección 3.4 y finalmente, con el número de estados óptimo obtenidos (2), se procedió a realizar la clasificación de forma convencional y a partir de la metodología de clasificación por capas desarrollada en este documento.

Tabla 4.7: Resultado validación cruzada de la clasificación convencional.

Número de estados	Media $\pm$ Desviación Estándar
2	$100 \pm 0,00$





Figura 4.10: Matriz de confusión del sistema de clasificación convencional empleando validación cruzada.

Tabla 4.8: Resultado de la validación cruzada para determinar el tipo de falla (Capa 1).


Número de estados	Media $\pm$ Desviación Estándar
2	$99,38 \pm 1,40$

Tabla 4.9: Resultado de la validación cruzada para determinar el nivel de degradación (Capa 2).

Número de estados	Media $\pm$ Desviación Estándar
2	99,41 $\pm$ 0,96



(a) Matriz de confusión del sistema de clasificación para determinar el tipo de patrón de falla (Capa 1).



(b) Matriz de confusión del sistema de clasificación para determinar el tipo de condición operacional (Capa 2).

Figura 4.11: Matriz de confusión del sistema de clasificación por capas.

Se observa que la precisión con la que se clasifican las señales de esta base de datos es muy alta. Al tener tan pocas clases, el sistema de clasificación es muy eficiente computacionalmente, haciendo innecesario emplear el método de clasificación por capas, dado que de forma convencional se entrenan 9 modelos por los 6 modelos que se entrenan en la clasificación por capas, la cantidad de modelos que se reducen no representan una disminución significativa del tiempo de computo, resultando impráctico.

# Capítulo 5

## Conclusiones

Se desarrolló una metodología para el diagnóstico de fallas y la identificación de condiciones operacionales de forma automática, ambas, son situaciones que afectan a las señales de vibración generadas por rodamientos de máquinas rotativas. A partir de esta metodología se encontró el mejor espacio de representación para caracterizar las señales, tal que, sus dinámicas intrínsecas sean más evidentes y de esta forma se pueda aprovechar al máximo la herramienta de reconocimiento de patrones utilizada. Para obtener estas características, inicialmente se dividieron las señales por segmentos de cuasi-estacionariedad, en los cuales el fenómeno del fallo y de la condición operacional estaba completamente descrito. Finalmente, las características que mejor resultado presentaron fueron los coeficientes cepstrales en frecuencia Mel propios de las señales de vibración.

Se comprobó que los modelos ocultos de Markov son una herramienta de reconocimiento de patrones robusta, que permite realizar una diferenciación entre muchas clases a partir de pocos estados y con un porcentaje de precisión alto. Esto es debido a que no está basado propiamente en diferenciar entre las características sino, en modelar la fuente a partir de la cual se generan estas características, resultando en una herramienta poderosa que puede modelar dinámicas diversas y similares de forma eficiente.

Se comprueba a partir de la validación cruzada anidada, lo que corresponde a una forma justa de sintonizar los parámetros libres de un modelo, que la estrategia de la poda de estados, es una metodología confiable y veraz al momento de obtener el número de estados óptimo de los modelos ocultos de Markov, siendo posible evitar, la carga computacional tan costosa que genera entrenar todos los modelos ocultos de Markov necesarios para llevar a cabo este tipo de validación, de esta forma, se puede obtener el número de estados óptimo de forma automática empleando criterios de teoría de la información. Se encontró que los parámetros libres necesarios para el modelado de las señales de vibración dependen del espacio de representación empleado, por lo tanto, la etapa de interpretación del fenómeno que se está estudiando es fundamental, al trabajar con HMMs, debido a que representan una metodología computacionalmente costosa, que fácilmente puede perder precisión a la vez que se aumenta el tiempo de computo.

Al realizar una clasificación por capas, el sistema se vuelve computacionalmente



---

más eficiente, lo cual podría ser beneficioso para aplicaciones en las que el monitoreo deba hacerse de forma rápida y eficiente, con un alto porcentaje de precisión al clasificar patrones de falla. Sin embargo, para fines de investigación el sistema es mucho más robusto, cuando se generan tantos modelos como clases haya en la base de datos.

# Bibliografía

- [1] H. Akaike, “Akaike’s Information Criterion,” *International Encyclopedia of Statistical Science*, pp. 25–25, 2011. [Online]. Available: <http://link.springer.com/10.1007/978-3-642-04898-2{-}110>
- [2] F. Al-Badour, M. Sunar, and L. Cheded, “Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques,” *Mechanical Systems and Signal Processing*, vol. 25, no. 6, pp. 2083–2101, 2011.
- [3] M. Bicego, V. Murino, and M. A. T. Figueiredo, “A sequential pruning strategy for the selection of the number of states in hidden Markov models,” *Pattern Recognition Letters*, vol. 24, no. 9-10, pp. 1395–1407, 2003.
- [4] C. Bishop, “Pattern recognition and machine learning (information science and statistics), 1st edn. 2006. corr. 2nd printing edn,” *Springer, New York*, 2007.
- [5] H. A. Blandón Hurtado and Y. F. Martínez Mendoza, “Desarrollo de una metodología para detección de fallas a partir del análisis de vibraciones en rodamientos usando características de tiempo y modelos ocultos de Markov (HMM),” Proyecto presentado como requisito parcial para optar al título de Ingeniero Electricista, Universidad Tecnológica de Pereira, 2013. [Online]. Available: <http://recursosbiblioteca.utp.edu.co/tesis/index.html>
- [6] T. Boutros and M. Liang, “Detection and diagnosis of bearing and cutting tool faults using hidden Markov models,” *Mechanical Systems and Signal Processing*, vol. 25, no. 6, pp. 2102–2124, 2011. [Online]. Available: <http://dx.doi.org/10.1016/j.ymssp.2011.01.013>
- [7] C. S. Burrus, R. a. Gopinath, and H. Guo, *Introduction to Wavelets and Wavelet Transforms: A Primer*, Prentice Hall, Ed., 1998. [Online]. Available: <http://www.amazon.com/Introduction-Wavelets-Wavelet-Transforms-Primer/dp/0134896009>
- [8] Case Western Reserve University, “Case Western reserve Data base.” [Online]. Available: <https://csegroups.case.edu/bearingdatacenter/pages/download-data-file>
- [9] J. J. Dziak, D. L. Coffman, S. T. Lanza, and L. Runze, “Sensitivity and specificity of information criteria,” *The Methodology Center*, vol. 12, no.

- 119, pp. 1–30, 2012. [Online]. Available: <http://methodology.psu.edu/media/techreports/12-119.pdf>
- [10] S. Goedecker, “Transformations on Computers With Overlapping,” vol. 18, no. 6, pp. 1605–1611, 1997.
- [11] R. Heng and M. Nor, “Statistical analysis of sound and vibration signals for monitoring rolling element bearing condition,” *Applied Acoustics*, vol. 53, no. 1-3, pp. 211–226, 1998. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0003682X97000182>
- [12] D. M. Herrera Obando, “Identificación automática de fallas en rodamientos de máquinas rotativas a partir de señales de vibraciones mecánicas empleando modelos ocultos de Markov con selección automática del número de estados,” Proyecto presentado como requisito parcial para optar al título de Ingeniero Electricista, Universidad Tecnológica de Pereira, 2016. [Online]. Available: <http://recursosbiblioteca.utp.edu.co/tesisd/index.html>
- [13] Y. R. Hwang, K. K. Jen, and Y. T. Shen, “Application of cepstrum and neural network to bearing fault detection,” *Journal of Mechanical Science and Technology*, vol. 23, no. 10, pp. 2730–2737, 2009.
- [14] J. M. Lee, S. J. Kim, Y. Hwang, and C. S. Song, “Diagnosis of mechanical fault signals using continuous hidden Markov model,” *Journal of Sound and Vibration*, vol. 276, no. 3-5, pp. 1065–1080, 2004.
- [15] C. Li, R.-V. Sánchez, G. Zurita, M. Cerrada, and D. Cabrera, “Fault Diagnosis for Rotating Machinery Using Vibration Measurement Deep Statistical Feature Learning,” *Sensors*, vol. 16, no. 6, p. 895, 2016. [Online]. Available: <http://www.mdpi.com/1424-8220/16/6/895>
- [16] Q. Miao and V. Makis, “Condition monitoring and classification of rotating machinery using wavelets and hidden Markov models,” *Mechanical Systems and Signal Processing*, vol. 21, no. 2, pp. 840–855, 2007.
- [17] J. R. Movellan, “Tutorial on hidden Markov models,” *Machine perception laboratory online tutorials*, 2003. [Online]. Available: <http://mplab.ucsd.edu/tutorials/pdfs/hmm.pdf>
- [18] K. P. Murphy, “Hidden Markov Model (HMM) Toolbox for Matlab,” 1998. [Online]. Available: <https://www.cs.ubc.ca/murphyk/Software/HMM/hmm.html>
- [19] S. Panchapagesan and A. Alwan, “Frequency warping for VTLN and speaker adaptation by linear transformation of standard MFCC,” *Computer Speech and Language*, vol. 23, no. 1, pp. 42–64, 2009.

- [20] M. D. Proakis J.G., *Digital signal processing*, 4th ed. Prentice Hall, 2006. [Online]. Available: <http://gen.lib.rus.ec/book/index.php?md5=50CB5F641B86F0D5F1643012E7E47400>
- [21] V. Purushotham, S. Narayanan, and S. a.N. Prasad, “Multi-fault diagnosis of rolling bearing elements using wavelet analysis and hidden Markov model based fault recognition,” *NDT & E International*, vol. 38, no. 8, pp. 654–664, 2005.
- [22] L. Rabiner, “A tutorial on hidden Markov models and selected applications in speech recognition,” *Proceedings of the IEEE*, vol. 77, no. 2, pp. 257–286, 1989.
- [23] K. S. Shanmugan and A. M. Breipohl, *Random Signals: Detection, Estimation and Data Analysis*, 1988.
- [24] J. Urbanek, T. Barszcz, M. Strackiewicz, and A. Jablonski, “Normalization of vibration signals generated under highly varying speed and load with application to signal separation,” *Mechanical Systems and Signal Processing*, vol. 82, pp. 13–31, 2017.
- [25] G. Zhai, J. Chen, C. Li, and G. Wang, “Pattern recognition approach to identify loose particle material based on modified MFCC and HMMs,” *Neurocomputing*, vol. 155, pp. 135–145, 2015. [Online]. Available: <http://dx.doi.org/10.1016/j.neucom.2014.12.039>